

Champs de Markov en Vision par Ordinateur

0 : Quelques Points avant Commencer : Contacts.

- Florent.Lafarge@inria.fr.
- www-sop.inria.fr/ariana/personnel/Florent.Lafarge
- Vous trouverez là l'original de ce document.

0 : Quelques Points avant Commencer : Vous.

- N'ayez pas peur :
 - De *questionner* - la façon meilleure d'apprendre.
 - De demander que je *répète* ou *explique* quelque chose.
 - De me dire si le niveau est *trop simple* ou *trop compliqué*.
- Envoyez-moi un *email* si vous avez des questions après le cours.

Buts.


- **Définitions** : qu'est-ce que sont les champs de Markov ?
- **Exemples** : comment sont-ils utilisés pour la compréhension d'images ?
- **Algorithmes** : comment peut-on extraire l'information désirée des modèles ?

Quelques elements simples d'une image



Notion de pixel

Définition : Un pixel est l'unité indivisible permettant de coder l'information relative à la luminosité en une certaine position



- les pixels sont généralement carrés
- pixel vient de « picture element »
- La taille du pixel





image numérique

Une image est un tableau de pixels : si le nombre de lignes vaut nl et le nombre de colonnes nc :



Un pixel est donc composé :

- de coordonnées (i, j) permettant de le situer,
- d'une valeur $v = p(i, j)$ représentant sa couleur .

image numérique

On peut voir l'image comme une fonction u et donc une surface.

$$u : I \times J \rightarrow V \\ (i, j) \rightarrow p(i, j)$$

"A un point on associe une valeur d'intensité"

En discret

$$I = \{0, \dots, nl - 1\} \text{ et, par exemple :} \\ J = \{0, \dots, nc - 1\} \quad V = \{0, \dots, 255\}$$

En continu

$$I = [0, 1] \text{ et :} \\ J = [0, L] \quad V = [0, 1]$$

L'avantage d'une telle représentation continue vient de la possibilité de dériver...

Formulation classique d'un problème en image


Entrée : une (ou plusieurs) image(s) où à chaque site est associé une intensité

Sortie : un ensemble d'étiquettes


Images : Deconvolution.




Images : Débruitage.




Images : Segmentation.



Images : Segmentation.




Images : estimation de mouvement.




Images : extraction de réseaux.



Images : extraction de réseaux.



Images : extraction de réseaux.



Part I : Définitions

problème inverse en image

soient: y , l'observation
 x , l'étiquette

on veut retrouver x à partir des informations
contenues dans y

la modélisation bayésienne

soient: y , l'observation
 x , l'étiquette

On cherche donc x sachant y :

$$\Pr(X = x / Y = y) = \frac{\Pr(Y = y / X = x) \cdot \Pr(X = x)}{\Pr(Y = y)} \quad \text{Loi de Bayes}$$

$\Pr(X = x / Y = y) \propto$	$\Pr(Y = y / X = x)$	$\Pr(X = x)$
↓	↓	↓
probabilité a posteriori de x	formation des observations	a priori

la modélisation bayésienne

- La probabilité de l'image sachant la scène (la formation de l'image). Souvent un modèle physique. Appelée la **vraisemblance**.
- La probabilité de la scène avant d'avoir vu l'image. Appelée la probabilité **a priori**.
- On doit construire des modèles pour **tous les deux**.

la modélisation bayésienne

on cherche la configuration d'objets x qui maximise la probabilité $P(X=x / Y=y)$

→ estimateur MAP : $\hat{x} = \arg \max_{x \in \Omega} \Pr(X = x / Y = y)$

Probabilités sur ces espaces.

- L'espace d'images est énorme juste pour une image de 256*256 pixels
- Les probabilités sont fonction de **65536** variables dépendantes : les valeurs des pixels. Donc, **il faut simplifier**.

Simplification de la probabilité.

- Les probabilités se simplifient quand quelques variables sont **indépendantes** les unes des autres.
- Les champs de Markov sont **une possibilité** (mais pas la seule) pour définir des probabilités **simplifiées** mais encore **utiles**.

Exemple : Indépendance.

- Si la scène est décrite par une fonction sur D , la probabilité peut **se factoriser** sur les pixels s de l'ensemble des sites de l'image S :

$$\Pr(X|Y) = \prod_{p \in D} \Pr(X_p | Y_p)$$

- Dans ce cas, on peut traiter chaque pixel **séparément** (problème à une dimension).

Champs de Markov (MRFs).

$V = \{V(s)/s \in S\}$ est un système de voisinage si

- $s \notin V(s)$
- $s \in V(t) \Leftrightarrow t \in V(s)$

De plus, on appelle **clique**, un sous-ensemble c de S dont les sites sont voisins deux à deux. On note C , l'ensemble de toutes les cliques associées à (S, V) .

Champs de Markov (MRFs).

Soit $X = (X_s)_{s \in S}$ un champ aléatoire associé à l'espace probabilisé complet (Ω, \mathcal{F}, P) .
 X est un **champ de Markov** relativement au système de voisinage V si

$$\forall x \in \Omega, \forall s \in S, P(X_s = x_s | X_r = x_r, r \in S - \{s\}) = P(X_s = x_s | X_r = x_r, r \in V(s))$$

Théorème de Hammersley-Clifford.

Le théorème suivant permet de caractériser la distribution d'un tel champ : c'est le théorème d'Hammersley-Clifford.

Théorème 2 (Hammersley-Clifford)

Soit X un champ de Markov associé à l'espace probabilisé (Ω, \mathcal{F}, P) , et tel que $\forall x \in \Omega, P(X = x) > 0$.

Alors, la distribution $P(X)$ de ce champ est une distribution de Gibbs :

$$P(X) = \frac{\exp -U(X)}{Z}$$

où $U(X) = \sum_{c \in C} V_c(X_s, s \in c)$ et $Z = \sum_{X \in \Omega} \exp -U(X)$

Distribution de Gibbs B.

- U est appelé l'énergie. Z est appelé le fonction de partition.
- Pour une distribution de Gibbs, l'estimée MAP prend une forme simple:

$$x^* = \arg \min U(x)$$

- Cette forme on appelle **minimisation d'énergie**.

Quel model pour l'a priori ?

- Étiquette binaire: **Ising**
- Étiquette non-binaire: **Potts** $U_r(x_r, x_r) = \begin{cases} 0 & \text{si } x_r = x_r \\ \beta & \text{sin on} \end{cases}$
- ou créer le modèle a priori que l'on veut !

exemple 1

Intensité = {rouge clair, rouge foncé, bleu clair, bleu foncé} (y)
 Etiquette = {blanc, noir} (x)

image d'entrée

Image de sortie

exemple 1

Intensité = {rouge clair, rouge foncé, bleu clair, bleu foncé} (y)
 Etiquette = {blanc, noir} (x)

image d'entrée

Modèle énergétique : $U(x) = U_{data}(x) + U_{prior}(x)$
 $= \sum_{s \in S} U_d(x_s) + \sum_{s \in S} \sum_{s' \in V(s)} U_p(x_s, x_{s'})$

- $U_d(x_s) = \begin{cases} 0 & \text{si } (x_s = \text{'blanc'} \cap y_s = \text{'rouge'}) \cup (x_s = \text{'noir'} \cap y_s = \text{'bleu'}) \\ 1 & \text{sinon} \end{cases}$
- $U_p(x_s, x_{s'}) = \begin{cases} 0 & \text{si } x_s = x_{s'} \\ \beta & \text{sinon} \end{cases}$
- Voisinage : 4-connextité

exemple 1

Intensité = {rouge clair, rouge foncé, bleu clair, bleu foncé} (y)
 Etiquette = {blanc, noir} (x)

image d'entrée

Questions:

- 1- quelle est la configuration x qui minimise la vraisemblance $U_{data}(x)$?
- 2- quelle est la configuration x qui minimise l'a priori $U_{prior}(x)$?
- 3- quelle est l'énergie des trois configurations suivantes ?
 Quelle est la meilleure configuration ?

4- meme questions mais avec un voisinage en 8-connextité

exemple 2

Question:
 Pour quelles valeurs de β , la solution optimale est-elle la suivante en 4-connextité ?